EV

1800/189

ROMANIA

REC'D 31 MAY 2000
WIPO PCT

OFICIUL DE STAT PENTRU INVENȚII ȘI MĂRCI

Nr.1006540/03.05.2000

CERTIFICAT DE PRIORITATE

Nr.007/03.05.2000

PRIORITY DOCUMENT

SUBMITTED OR TRANSMITTED IN COMPLIANCE WITH RULE 17.1(a) OR (b)

Certificăm că descrierea enexată este copia identică a descrierii invenției cu titlul:

"RECUNCASTEREA VORBIRII SI ANALIZA SEMNALELOR PRIN CAUTAREA DIRECTA A SUBSECVENTELOR CU MASURI MAXIME DE INCREDERE"

DIRECTOR GENERAL

TOR GEN





1 Domeniile tehnice in care inventia poate fi utilizata sint

- Recunoasterea Vorbirii,
- Recunoasterea Cuvintelor Cheie,
- Analiza si Recunoasterea Imaginilor,
- Recunoasterea Segmentelor În Studiul Materiilor Organice (Studiul Genomului)

2 Stadiul tehnicii

- La recunoasterea cuvintelor cheie se utilizeaza adesea reprezentarea segmentelor nedorite printr-un model atotcuprinzator de umplutura <Garbage/Filler Models>. Se utilizeaza modele fonetice dependente/independente de context si fara constringeri lexicale. Se efectueaza apoi o estimare <VITERBI> (probabilitatea maxima a unei cai), procedura inainte-inapoi (probabilitatea considerind toate caile) sau o reducere a modelului la Programare Dinamica. O alternativa permite relaxarea constringerii asupra pozitionarii punctelor de inceput si de sfirsit ale cuvintelor in secventele rostite [3]. Dar aceasta necesita o normalizare ulterioara.
- Una din cele mai performante metode actuale realizeaza recunoasterea cuvintelor cheie prin modelarea segmentelor nedorite utilizind media celor mai performante K corespondente in esantion. [2]
- Studiul genomului se face, in anumite laboratoare (ISREC), pe baza reprezentarii secventelor distante de proteine cu functionalitati comune sub forma unor modele numite 'Profile Generalizate'. Cu ajutorul acestora se cauta subsecventele corespondente de DNA. Algoritmul este

20.

5.

10.

15.

bazat pe Programarea Dinamica cu modificari minore datorate specificitatii modelului. Deoarece calculele necesare sint extrem de costisitoare, sisteme paralele de pina la 16 calculatoare (INSECT) sint utilizate. In aceste zile, o implementare hardware bazata pe FPGA-uri a fost realizata [4]. Aceasta calculeaza in jur de 7 milioane celule esantion-stare pe secunda.

 Pentru recunoasterea obiectelor in imaginii exista o gama larga de metode. Se utilizeaza cross-corelatia, 'snakes', analiza trasaturilor, a texturii, a culorii, etc. Metodele au avantaje si dejavantaje diferite pentru fiecare aplicatie. In domeniul cartografiei se utilizeaza adesea 'snakes' ce trebuie initializati de catre operator. In domeniul roboticii se utilizeaza, printre altele, analiza contururilor si cross-corelatia proiectiilor.

3 Expunerea Inventiei

5.

10.

25.

30.

Descriem inventia utilizind notatii si termeni legati de recunoasterea vorbirii si utilizind probabilitati posteriorioare. Metodele ramin identice daca se folosesc probabilitati sau alte tipuri de aproximare a acestora bazate pe aplicatia corespunzatoare, ca de exemplu anumite distante intre valorile culorii pixelilor. Scorurile utilizate in profilele secventelor biomoleculare sint de asemenea acceptabile pentru estimari de posteriori.

Deasemenea noi folosim minusul logaritmului posteriorilor. Metoda este desigur identica daca se folosesc logaritmi pozitivi cu schimbarea semnului comparatiilor. Acestea sind detalii de implementare.

3.1 Descrierea teoretica a problemei

In Recunoasterea Vorbirii s-a recomandat [1] utilizarea de masuri de confidenta (incredere) pentru reestimarea primelor N ipoteze. Modele propuse contin normalizarea probabilitatii posterioare cumulate peste lungimea secventei recunoscute. O alta masura este dubla normalizare peste numarul de foni si numarul de esantioane acustice in fiecare fon. Aceste masuri nu pot fi calculate direct utilizind Viterbi deoarece factorul de normalizare este diferit pentru cai de lungimi diferite.

Fie $X = \{x_1, x_2, \dots, x_n, \dots, x_N\}$ secventa esantioanelor acustice in care cautam subsecventa W representata ca un Model Markov Ascuns (HMM)

inainte M avind starile: $Q = \{q_1, q_2, \ldots, q_\ell, \ldots, q_L\}$. In spiritul consideratiilor asupra masurilor de incredere cu normalizare simpla, potrivind M cu subsecventa $X_b^e = \{x_b, \ldots, x_e\}$ si utilizind starea de umplutura q_G^e inainte si dupa M, obtinind un HMM M', putem calcula logaritmul posterior al modelului M, in modul urmator:

$$-\log P(M|X_{b}^{e}) \simeq \frac{1}{e-b+1} \min_{\forall \overline{Q} \in M} -\log P(\overline{Q}|X_{b}^{e})$$

$$\simeq \frac{1}{e-b+1} \min_{\forall \overline{Q} \in M} \left\{ -\log P(q^{b}|q_{G}) - \sum_{n=b}^{e-1} [\log P(q^{n}|x_{n}) + \log P(q^{n+1}|q^{n})] - \log P(q^{e}|x_{e}) - \log P(q_{G}|q^{e}) \right\}$$
(1)

unde $\overline{Q} = \{q^b, q^{b+1}, ..., q^e\}$ reprezinta una din caile de lungime e - b + 1 in M, iar q^n este starea HMM vizitata la momentul n de-a lungul lui \overline{Q} . q_G reprezinta modelul de umplutura.

Pentru Recunoasterea Cuvintelor Cheie, definim scorul de recunoastere ca:

$$S(M|X) = \min_{\forall \{b,e\}} -\log P(M|X_b^e)$$
 (2)

15 si notam cu:

5.

$$\langle \overline{S'}, in, out \rangle = \underset{\{\overline{Q}, b, e\}}{\operatorname{argmin}} \frac{1}{e - b + 1} - \log P(\overline{Q}|X_b^e)$$
 (3)

Cu $Q=\{\overbrace{q_G,...q_G}^{b-1},q^b,q^{b+1},...,q^e,\overbrace{q_G,...q_G}^{N-e}\}$, notam calea ce extinde \overline{Q} cu b-1 stari q_G inaintea lui q^b si N-e stari q_G urmind q^e . In cazul utilizarii starilor de umplutura, calea S' este de obicei estimata:

$$2 \theta \cdot S' \simeq \underset{\forall Q \in M'}{\operatorname{argmin}} - \log P(Q|X) \\
\simeq \underset{\forall Q \in M'}{\operatorname{argmin}} \left\{ -\sum_{n=1}^{b-1} \log P(q_G|x_n) - \log P(q^b|q_G) \right. \\
\left. -\sum_{n=b}^{e-1} \left[\log P(q^n|x_n) + \log P(q^{n+1}|q^n) \right] - \log P(q^e|x_e) \right. \\
\left. -\log P(q_G|q^e) - \sum_{n=e+1}^{N} \log P(q_G|x_n) \right\} \tag{4}$$

pentru care $P(q_G|x_n)$ este egala cu o constanta ε sau cu o variabila ca in cazurile mentionate in stadiul tehnicii. Aceast procedeu nu conducea in general la solutia definita in (2) si (3). In spiritul normalizarii simple noi propunem metoda Programarii Dinamice Iterative, descrisa in continuare, pentru calcularea unei valori pentru ε ce garanteaza obtinerea segmentarii 'optime' definite in (2). Acelasi rezultat ar putea fi obtinut prin normalizarea posteriorului cumulat pentru toate perechile posibile de puncte de inceput si sfirsit, si ar necesita un numar de teste proportional cu patratul lungimii secventei in care se cauta. Metoda inventata are calitatea aditionala de Timp Real la normalizarea simpla.

Vom nota cu S_a^b calea S in HMM M' daca ea intra la esantionul b in starea q_1 din starea q_G si iese la esantionul e din starea q_L spre starea q_G .

Daca un obiect necesita pentru reprezentarea sa HMM tranzitii inapoi, se va realiza reprezentarea sa utilizind mai multe modele HMM inainte si care vor fi tratate ca subsecvente diferite.

3.2 Metoda cu Normalizare Simpla

Metoda iterativa de calculare a lui ε :

- 1. ε se initializeaza cu $Valoarea_De_Initializare$
- 2. $\langle w', S \rangle = \text{Viterbi}(\varepsilon)$
- 20. 3. ciclu: S'=S $\varepsilon = w'$

10.

- 4. $< w', S > = Viterbil(\varepsilon)$
- 5. daca S' diferit de S
 mergi la pasul 3 (ciclu)
 altfel
 raporteaza raspunsul S' retestat cu masuri aditionale de incredere

Unde submetoda ViterbiI consta in: ViterbiI(ε)

30. 1. Calculeaza calea S_b^e folosind Viterbi clasic al M' peste X.

2.
$$w = -\log P(M|X_b^e)$$

3. Raporteaza < w, S >

Valoarea de initializare a lui ε se poate alege la intimplare fara pierderea convergentei. Noi am obtinut rezultate foarte bune initializind-ul cu valoarea logaritmului posteriorului obtinut cu metodele descrise in starea tehnicii. In toate testele, aceasta metoda a convers in maximum 4 iteratii.

Demonstratiile corectitudinii vor fi publicate in scurt timp in literatura internationala de specialitate.

Metoda este de citeva ordine de marime mai rapida decit alte abordari care ar garanta optimul teoretic definit de masura de incredere cu normalizare simpla. In plus, ea nu necesita un spatiu in memoria de calcul mai mare decit nici una din metodele cunoscute. Rezultatele in recunoasterea cuvintelor cheie se compara pozitiv cu rezultatele tehnicilor ce le cunoastem.

3.3 Metoda cu Normalizare Dubla

15. Masura de incredere corespunzatoare se defineste ca:

20.

25.

$$\frac{1}{Nr.Foni\ Parcursi} \sum_{fon_i \in Fonii\ Parcursi} \frac{\sum_{fon_i} -\log posteriori}{lungime\ fon_i}$$
 (5)

Aceasta metoda consta intr-un algoritm de tip 'breadth first Beam search' caracterizat de absenta modelului de umplutura, un set complex de reguli de reducere si de efectuarea anumitor normalizari:

Starea q_G are in aceasta metoda logaritmul posteriorului de emisie 0. Pentru fiecare esantion e si pentru fiecare stare s se calculeaza setul de probabilitati/cai de a avea esantionul e in starea s, ca primele N maxime ale masurii de confidenta pentru caile in HHM M' de lungime e si care se termina cu starea s. Se pot elimina, deasemenea, cele care, potrivit regulilor de reducere, vor pierde cu siguranta cursa finala in favoarea unor cai deja cunoscute.

Notam cu a_1 , p_1 , l_1 , a_2 , p_2 si l_2 masura de incredere pe fonii precedenti, posteriorul in fonul curent si lungimea in fonul curent pentru calea Q_1 respectiv Q_2 . Regulile ce pot fi utilizate la reducerea spatiului cailor, 'pruning', pentru eliminarea lui Q_1 in favoarea lui Q_2 pot fi in acest caz fiecare din urmatoarele:

1.
$$l_2 \ge l_1$$
, $A > 0$, $B \le 0$ si $L_c^2 A + L_c B + C \ge 0$

- 2. $l_2 \ge l_1$, $A \ge 0$, $B \ge 0$ si $C \ge 0$
- 3. $l_2 \ge l_1$, $A \le 0$, $C \ge 0$ si $L^2 A + LB + C \ge 0$
- 4. $l_2 \ge l_1$, A = 0, B < 0 si $LB + C \ge 0$

unde $A = a_1 - a_2$, $B = (a_1 - a_2)(l_1 + l_2) + p_1 - p_2$, $C = (a_1 - a_2)l_1l_2 + p_1l_2 - p_2l_1$, $E = L_{max} - \max\{l_1, l_2\}$, $L_c = -B/2A \ge 0$ iar L_{max} este lungimea maxima acceptata pentru un fon - echivalentul lungimii acceptate a unei stari din abordarile clasice.

Eliminarea unei cai doar daca una din aceste reguli e satisfacuta, garanteaza optimul definit de masura de incredere cu normalizare dubla, daca nici un fon nu poate fi evitat de HMM-ul M utilizat. Fiecare HMM inainte poate fi descompus in HMM-uri cu aceasta calitate. Regula a 4-a este inclusa in regula a 3-a si testarea sa e inutila daca aceasta din urma a fost deja testata.

Primul test, $l_2 \geq l_1$ ne spune de fapt daca Q_2 are sanse sa elimine Q_1 , in caz contrar se va verifica daca Q_1 elimina Q_2 . Aceste teste se deduc din conditiile asigurarii masurii de incredere maxime dupa efectuarea reducerilor. Pentru a utiliza metoda dublei normalizari fara a descompune HMM-uri ce evita anumiti foni, regulile anterioare se modifica considerind numarul de foni anteriori pentru fiecare cale F_1 respectiv F_2 si numarul de foni ce pot urma starii curente.

20. Un test simplificat poate fi:

25.

30.

• $l_2 \ge l_1$, $A \ge 0$, $p_1 \ge p_2$ respectiv $F_2 \ge F_1$ in cazul HHM-urilor ce pot evita foni.

Acest test este mai slab decit regula 2. Exemplu: O cale este eliminata de o alta daca prima are o masura de confidenta inferioara (numeric mai mare) pe fonii anteriori, o lungime mai mica si minusul logaritmului posteriorului cumulat in fonul curent deasemenea inferior (numeric mai mare) celei de a doua. O masura aditionala de incredere bazata pe lungimea maxima, L_{max} , si pe maximul minusului logaritmului posteriorului cumulat si normalizat in fon, P_{max} , e utila pentru garantarea unei limitari puternice a numarului de cai stocate.

- $p > L_{max}P_{max}$ intr-o stare oarecare
- $\frac{p}{l} > P_{max}$ la iesirea din fon

unde p si l sint valorile in fonul curent pentru minusul logaritmului posteriorului cumulat si pentru lungimea caii ce se elimineaza. Aceste teste permit eliminarea cailor prea lungi si care nu sint deosebit de performante, respectiv a cailor cu foni avind un scor inacceptabil, compensat de scoruri foarte bune in alti foni.

Daca N se alege ca unu, regulile mentionate nu mai sint necesare, ci intotdeauna se propaga calea cu estimarea curenta a masurii de incredere maxime. Rezultatele obtinute sint deosebit de bune, chiar daca optimul definit se garanteaza pentru aceasta metoda doar cind N este mai mare ca lungimea secventei permise de L_{max} sau a secventei ce se testeaza.

Aceeasi abordare e functionala pentru normalizarea simpla unde HMM-ul subsecventei va fi format dintr-un singur fon.

3.4 Metoda Potrivirii Reale

5.

25.

Noi am definit, de asemenea, o noua masura de incredere care reprezinta bine cerintele recunoasterii. Deoarece fonii si starile absente pot fi modelate de catre HMM-urile utilizate, este normal sa se ceara potrivirea fiecarui fon din model cu o portiune din secventa. Prin urmare, noi consideram masura de incredere a unei subsecvente ca fiind egala cu maximul pentru toti fonii, a minusului logaritmului posteriorului cumulat al fonului, normalizat cu lungimea sa.

$$\max_{fon \in Foni\ Parcursi} \frac{\sum_{fon} -\log\ posteriori}{lungime\ fon} \tag{6}$$

Regula ce poate fi utilizata in acest cadru la reducerea numarului de cai explorate este:

• Q_2 se elimina in favoarea altei cai Q_1 daca masura de incredere a potrivirii reale pentru fonii anteriori este inferioara (numeric superioara) pentru Q_2 fata de Q_1 , si daca $p_1 \leq p_2$ si $l_2 \leq l_1$

unde p_1 , l_1 , p_2 , l_2 reprezinta minusul logaritmului posteriorului cumulat respectiv lungimea masurata in esantioane in fonul curent pentru calea Q_1 respectiv Q_2 .

Asemenea metodei precedente, limitarea numarului de cai considerate se face prin eliminarea celor care corespund criteriilor:

• $p > L_{max}P_{max}$ intr-o stare oarecare

• $\frac{p}{l} > P_{max}$ la iesirea din fon

unde p si l sint valorile in fonul curent pentru minusul logaritmului posteriorului cumulat si pentru lungimea caii ce se elimineaza. Amintim ca semnificatiile constantelor sint lungimea maxima, L_{max} , si respectiv maximul acceptat al minusului logaritmului posteriorului cumulat si normalizat in fon, P_{max} .

3.5 Performante

5.

Metodele prezentate anterior au fost testate in forma descrisa la punctul 4.2. Implementarea a testat aplicarea acestora pentru recunoasterea cuvintelor cheie. S-a construit curba ROC si s-a constatat ca metodele au dat rezultate superioare celor publicate in literatura de specialitate pentru alte experiente. Metoda dublei normalizari a dat rezultate superioare metodei simplei normalizari.

4 Obiectul Inventiei

4.1 Objectul inventiei consta in:

- metoda de recunoastere a subsecventelor utilizind calculul direct de masuri de incredere.
 - masura de incredere si metoda de recunoastere numita 'potrivire reala' si bazata pe potrivirea separata a fiecarui fon.
 - metodele de recunoastere utilizind normalizarea simpla si dubla
- insotirea acestor masuri cu masurile aditionale de incredere mentionate aici, respectiv normalizarea dubla, lungimea maxima si limitarea potrivirii reale
 - Utilizarea metodelor anterioare la recunoasterea cuvintelor cheie
- Utilizarea metodelor anterioare la recunoasterea subsecventelor in structura materiilor organice
 - Utilizarea metodelor anterioare la recunoasterea de obiecte in imagini

/c

4.2 Mod de executare, folosire si functionare

Executarea: Este necesar un sistem de calcul, dar metoda poate de asemenea fi utilizata intr-o implementare hardware.

- Se va obtine o reprezentare sub forma HMM a subsecventelor cautate (cuvint, profil proteine, sectiune imagine object).
 - Se obtine un instrument (eventual antrenat Ex: pentru recunoasterea vorbirii) de estimare a posteriorilor. De exemplu multi-gausiani, retele neuronale, clusteri, baze de date cu Profile Generalizate, etc.
 - Se implementeaza unul din algoritmii propusi.
- 10. Pentru primul algoritm

15.

20

25.

30.

- ViterbiI se implementeaza utilizind algoritmul clasic Viterbi cu modificarea ca, pentru fiecare pereche $P = \langle esantion, stare \rangle$ se propaga si momentele tranzitiilor intre starea q_G si starile HMM M a caii ce ajunge la P. Acestea se mostenesc de la calea ce cistiga intrarea in perechea P, cu exceptia momentului cind se face decizia lor si anume cind ele primesc valoarea esantionului corespunzator.
- $-w = -\log P(M|X_b^e)$ se calculeaza scazind din posteriorul cumulat calculat de algoritmul Viterbi pentru calea Q_b^e valoarea $(N-(e-b+1))*\varepsilon$ corespunzind umpluturii si divizind rezultatul prin e-b+1. Desigur, factorul e-b+1 din formula precedenta va fi scos in afara fractiei.
- Initializarea lui ε se face cu o valoare medie asteptata. Se poate folosi si w calculat cind starea q_G este asociata cu un posterior de emisie egal cu media celor mai bune K probabilitati de emisie ale esantionului curent. In acest caz, K se antreneaza utilizind tehnicile actuale cunoscute.

Algoritmii urmatori, de tip 'Beam search', se implementeaza dupa descrierea din sectiunea corespunzatoare. Pentru fiecare pereche $P = \langle esantion, stare \rangle$ se calculeaza pentru fiecare cale asociata suma si lungimea din ultimul fon, precum si suma peste cumulul normalizat al fonilor precedenti (si numarul lor). Deasemenea, esantioanele de intrare si iesire in/din HMM-ul M sint calculate si propagate ca in metoda precedenta, pentru a asigura localizarea subsecventei.

- Daca una si aceeasi subsecventa poate avea mai multe modele HMM, toate acestea se iau in considerare ca competitori. Acesta e cazul cuvintelor cu multiple moduri de pronuntie sau obiectelor ce pot fi vazute diferit in diferite stari, pentru recunoasterea acestora in imagini.
- Dupa calculul masurii de incredere pentru fiecare model de subsecventa, se elimineaza cele cu o masura de confidenta in dezacord cu un 'threshold' antrenat pentru configuratia si scopul aplicatiei. De exemplu, pentru recunoasterea vorbirii cu retele neuronale si minus al logaritmului posteriorilor se va alege un 'threshold' maximal in punctul de functionare dorit al curbei ROC obtinuta in teste.
- Alternativele ramase se extrag in ordinea masurii de incredere si cu eliminarea alternativelor in conflict pina la epuizare. De fiecare data cind o alternativa e eliminata, subsecventa cautata cu HMM corespunzator e reestimata pentru portiunea ramasa disponibila ei in secventa in care se opereaza cautarea. Daca noua masura de incredere promoveaza testul 'threshold'-ului, atunci ea va fi inserata in pozitia corespunzatoare valorii in coada de alternative.
- Alternativele cu succes pot suporta teste de nivel superior ca de exemplu o intrebare de confirmare pentru recunoasterea vorbirii, opinia unui operator, etc.
 - Pentru recunoasterea obiectelor in imagini:

25

30.

Posteriorii se obtin prin calculul unei distante intre culoarea starii modelului si cea a elementului din sectiunea imaginii. Daca conditiile de utilizare o impun, imaginea va fi preprocesata pentru a asigura o anumita normalizare (Ex: conditii schimbatoare de lumina vor face necesara o transformare de corectie bazata pe histograma).

Fonilor din recunoasterea vorbirii le corespund parti ale obiectului. Structura (existenta tranzitiilor si probabilitatea lor) poate fi schimbata in functie de caracteristicile detectate ale caii curente. De exemplu, detectind zone ale obiectului cu anumite lungimi, putem estima lungimea asteptata a zonelor ramase. Se va stabili astfel numarul de esantioane asteptat pentru starile viitoare si se va configura corespunzator HMM-ul atasat obiectului.

Se va scana o directie pentru detectarea unei potriviri optime si ulterior se vor scana celelalte directii pentru a descoperii noi potriviri, cit si pentru a verifica cele existente. Testul final va fi certificat prin crosscorelatie sau prin analiza contururilor in pozitia generata de ipoteze.

5 Aplicare Industriala

Aici sint prezentate citeva exemple ale aplicatiilor metodei propuse in industrie:

- Recunoasterea Cuvintelor Cheie incepe sa fie utilizata in raspunzatoarele automate ale sistemelor bancare, telefonice precum si in automate de control, vinzare sau informare. Metoda ofera o posibilitate de recunoastere a cuvintelor cheie in vorbire continua cu vorbitori multipli.
- Recunoasterea secventelor in ADN este importanta in studiul genomului uman. Una din cele mai mari probleme ale tehnicilor implicate consta in marea cantitate de date ce trebuie prelucrate.
- Recunoasterea Obiectelor in Imagini isi are utilizarea, printre altele, in cartografie si in conducerea robotilor industriali. Metoda permite estimarea rapida a pozitiei obiectelor in scena si poate fi urmata de teste suplimentare utilizind metode clasice de cross-corelatie.

References

10

- 19. [1] G. Bernardis and H. Bourlard. Improving posterior based confidence measures in hybrid hmm/ann speech recognition systems. In *Proceedings to ICSLP'98 (Sydney, Australia)*, 1998.
- [2] H. Bourlard, B. D'hoore, and J.-M. Boite. Optimizing recognition and rejection performance in wordspotting systems. In Proc. of IEEE Intl. Conf. on Acoustics, Speech, and Signal Processing (Adelaide, Australia), pages I:373-376, 1994.
 - [3] J.S. Bridle. An efficient elastic-template method for detecting given words in running speech. In *Brit. Acoust. Soc. Meeting*, pages 1-4, 73.

[4] E. Mosanya. A Reconfigurable Processor for Biomolecular Sequence Processing. PhD thesis, Swiss Federal Institute of Technology EPFL, LSL, February 1999.

Revendicarea Independenta 1.

7 Preambul:

Realizeaza recunoasterea unor subsecvente reprezentate ca Modele Markov Ascunse(HMM), cautate intr-o secventa oarecare. Ne referim la masuri de incredere utilizate la reclasarea ipotezelor cistigatoare din Recunoasterea Vorbirii. Exemple de astfel de masuri sint:

10. normalizarea simpla

posteriorul cumulat normalizat cu

lungimea subsecventei

normalizarea dubla

dubla normalizare peste numarul de foni si peste numarul de esantioane acustice in fiecare fon al posterioru-

lui cumulat.

caracterizata prin aceea ca: Permite masura suplimentara a increderii bazate pe extremele valorilor logaritmului posteriorului cumulat al fiecarui fon, normalizat cu lungimea sa. Aceasta masura am denumit-o 'potrivirea reala'.

 $\max_{fon \in Foni\ Parcursi} \frac{\sum_{fon} -\log\ posteriori}{lungime\ fon}$

г O.

25

2g.

15

caracterizata prin aceea ca: Se cauta subsecventa ce ofera maximizarea uneia dintre masurile de incredere amintite, peste toate potrivirile posibile.

caracterizata prin aceea ca: Permite reevaluarea alternativelor ce ofera maximizarea unei masuri de incredere mentionata, pe baza altei masuri de incredere.

caracterizata prin aceea ca: Calculeaza alternativa ce maximizeaza 'nor-malizarea simpla' utilizind metoda ce noi am numit-o 'Programare Dinamica Iterativa' si care estimeaza posteriorul de emisie al starilor de umplutura, in mod iterativ, ca fiind egal cu masura de incredere in iteratia anterioara.

1/2

caracterizata prin aceea ca: Calculeaza alternativa ce maximizeaza 'normalizarea simpla', 'normalizarea dubla' sau 'potrivirea reala' prin utilizarea unui algoritm ce considera posteriorul de emisie al starii de umplutura ca nul. Aceasta metoda calculeaza progresiv, pentru fiecare pereche de esantion si stare a HMM, un set de alternative posibile de a ajunge acolo.

Calcularea acestui set se bazeaza pe seturile de alternative ce conduc la starile ce pot fi asociate esantionului anterior celui curent.

Acest set poate fi redus utilizind reguli caracteristice masurii de incredere si care asigura corectitudinea inferentei.

Acest set poate deasemenea fi redus utilizind heuristici bazate pe regulile mentionate, pentru a mari viteza de calcul cu riscul diminuarii calitatii teoretice a recunoasterii.

5.

Revendicarea Dependenta 2.

9. Preambul:

Bazata pe Revendicarea 1.

Realizeaza estimarea existentei cuvintelor cheie si a pozitiei lor in secvente rostite.

caracterizata prin aceea ca: Utilizeaza metodele descrise in Revendicarea 1. pentru recunoasterea subsecventelor reprezentate prin modele markov ascunse.

Revendicarea Dependenta 3.

5. Preambul:

Se bazeaza pe Revendicarea 1.

Estimarea existentei subsecventelor biomoleculare si pozitiei lor in lanturi ale moleculelor organice (ADN) utilizind modele de tipul profilelor generalizate.

10. caracterizata prin aceea ca: estimarea existentei si pozitiei se face cu metodele descrise in Revendicarea 1. pentru recunoasterea subsecventelor reprezentate prin Modele Markov Ascunse inainte.

Revendicarea Dependenta 4.

Freambul:

15.

Se bazeaza pe Revendicarea 1. Realizeaza estimarea existentei obiectelor si a pozitiei lor in imagini utilizind metodele descrise in Revendicarea 1. pentru recunoasterea subsecventelor reprezentate prin Modele Markov Ascunse.

caracterizata prin aceea ca: Sectiuni ale imaginii obiectelor sint modelate 10. prin seturi de Modele Markov Ascunse.

caracterizata prin aceea ca: se utilizeaza un model probabilistic bazat pe o distanta calculata intre culori.

caracterizata prin aceea ca: Modelele Markov Ascunse ce modeleaza obiectele pot fi structurate din parti distincte, ce joaca in cadrul metodei rolul fonilor.

caracterizata prin aceea ca: Modelele obiectelor pot sa isi modifice intr-un mod dinamic proprietatile tranzitiilor (existenta si probabilitatea) pe baza informatiei acumulate de algoritmul de potrivire.

Rezumat

Inventia se refera la metode de realizare a recunoasterii cuvintelor cheie in secvente rostite, a detectarii subsecventelor in lanturi de materii organice (ADN) si a recunoasterii obiectelor in imagini. Metodele cauta potrivirea ce maximizeaza, peste toate potrivirile posibile, anumite masuri de incredere bazate pe posteriori normalizati. Trei astfel de masuri de incredere sint exemplificate, doua fiind inspirate dintr-o alta operatie in Recunoasterea Vorbirii, iar una este noua.

This Page Blank (uspio)

This Page is Inserted by IFW Indexing and Scanning Operations and is not part of the Official Record

BEST AVAILABLE IMAGES

Defective images within this document are accurate representations of the original documents submitted by the applicant.

Defects in the images include but are not limited to the items checked:

BLACK BORDERS

IMAGE CUT OFF AT TOP, BOTTOM OR SIDES

FADED TEXT OR DRAWING

BLURRED OR ILLEGIBLE TEXT OR DRAWING

SKEWED/SLANTED IMAGES

COLOR OR BLACK AND WHITE PHOTOGRAPHS

GRAY SCALE DOCUMENTS

LINES OR MARKS ON ORIGINAL DOCUMENT

REFERENCE(S) OR EXHIBIT(S) SUBMITTED ARE POOR QUALITY

IMAGES ARE BEST AVAILABLE COPY.

As rescanning these documents will not correct the image problems checked, please do not report these problems to the IFW Image Problem Mailbox.

mis Page Blank (uspto)